

Определение параметров поверхностных дефектов основного металла трубопроводов по результатам комплексной диагностики

Н.В. Крысько¹, С.В. Скрынников², Н.А. Щипаков¹, Д.М. Козлов¹, А.Г. Кусый¹

¹ Федеральное государственное бюджетное образовательное учреждение высшего образования «Московский государственный технический университет имени Н.Э. Баумана (национальный исследовательский университет)»,

105005, г. Москва, ул. Бауманская 2-я улица, д. 5, стр. 1;

² ПАО «Газпром», 117997, г. Москва, ул. Наметкина, д. 16, ГСП-7

Аннотация

Рассмотрены вопросы определения параметров поверхностных эксплуатационных дефектов по результатам комплексной диагностики ультразвуковым, вихретоковым и визуальным и измерительным методами неразрушающего контроля. При этом визуальный и измерительный метод реализовался с применением камеры телевизионного контроля, оснащенной функцией компьютерного зрения, и лазерным триангуляционным датчиком. В работе представлен набор данных, в котором в качестве входных переменных находятся результаты неразрушающего контроля, а в качестве целевых переменных – глубина плоскостных и объемных дефектов, а также ширина объемных дефектов. Также в работе произведена оценка степени влияния различных результатов неразрушающего контроля на определение целевых переменных. Произведено обучение моделей на основе различных алгоритмов, в итоге для всех целевых переменных оптимальными моделями оказались модели на основе градиентного бустинга. Представлен алгоритм совместной обработки результатов при комплексной диагностике, в котором применяются полученные модели, и определена точность работы данного алгоритма по метрике RMSE, которая составила 0,011 мм.

Ключевые слова: поверхностные дефекты, ультразвуковой контроль, вихретоковый контроль, лазерное сканирование, комплексная диагностика, совместная оценка данных, машинное обучение, регрессия.

Цитирование: Крысько, Н.В. Определение параметров поверхностных дефектов основного металла трубопроводов по результатам комплексной диагностики / Н.В. Крысько, С.В. Скрынников, Н.А. Щипаков, Д.М. Козлов А.Г. Кусый // Компьютерная оптика. – 2025. – Т. 49, № 2. – С. 311-319. – DOI: 10.18287/2412-6179-CO-1437.

Citation: Krysko NV, Skrynnikov SV, Shchipakov NA, Kozlov DM, Kusy AG. Determining parameters of surface defects in the base metal of pipelines using results of complex diagnostics. Computer Optics 2025; 49(2): 311-319. DOI: 10.18287/2412-6179-CO-1437.

Введение

В настоящее время количество объектов трубопроводного транспорта продолжает увеличиваться. В работах [1–4] показано, что на данных объектах наибольшую часть эксплуатационных дефектов составляют поверхностные коррозионные повреждения, возникающие под воздействием внешней среды. Такие дефекты можно разделить на плоскостные, например, стресс-коррозионные трещины, и объемные – местная коррозия (питинги, свищи и т.д.) [5]. Для обеспечения длительной безопасной эксплуатации трубопроводов применяются автоматизированные сканеры-дефектоскопы, реализующие ультразвуковой, магнитный и вихретоковый методы неразрушающего контроля. Данные сканеры-дефектоскопы являются индикаторными приборами, которые обнаруживают только область, содержащую дефекты. Далее в данной области проводят подтверждающий ручной контроль визуальным и измерительным (ВИК), магнитным (МК), ультразвуковым (УК) и

вихретоковым (ВК) методами [6]. Ручной подтверждающий контроль является трудоемким процессом, при проведении которого присутствует субъективный человеческий фактор. Для исключения ручного подтверждающего контроля актуально применение технологий диагностирования с использованием комплекса методов неразрушающего контроля (НК), позволяющих производить классификацию эксплуатационных дефектов и определять их параметры в автоматическом режиме.

Результаты контроля данными методами, как правило, представляются в цифровом виде. Специализированные методы принятия решений на основе составных (а иногда и противоречивых) цифровых входных данных называют «слиянием данных» [7]. Слияние данных на основе нечеткой логики, статистических методов и машинного обучения сегодня широко применяется в науке и технике [8]. Принципы слияния данных уже активно применяются к различным задачам неразрушающего контроля в работах [9, 10].

В работе [11] была построена модель анализа данных на основе теории Демпстера–Шафера при комплексной диагностике УК и ВК, которая позволила определять тип поверхностных эксплуатационных дефектов (объемный или плоскостной) основного металла магистрального газопровода. Помимо определения типа, согласно требованиям нормативно-технической документации необходимо также определять параметры выявленных дефектов.

В данной работе рассматривается работоспособность моделей совместной обработки данных УК, ВК и ВИК на основе алгоритмов машинного обучения для определения параметров поверхностных эксплуатационных дефектов (задачи регрессии) основного металла трубопроводов. В работах [12–17] показано, что данные методы неразрушающего контроля по отдельности позволяют оценить глубину поверхностных эксплуатационных дефектов, но с определенной погрешностью, также при больших значениях глубин дефектов точность определения их параметров уменьшается. Результаты по определению параметров поверхностных эксплуатационных дефектов основного металла трубопроводов по результатам анализа данных комплексной диагностики такими методами, как УК, ВК и ВИК, не были найдены при анализе литературных данных, что свидетельствует об актуальности данной работы.

1. Методика проведения исследований

Для исследования возможностей определения параметров поверхностных эксплуатационных дефектов основного металла трубопроводов был изготовлен ряд образцов, содержащих имитаторы поверхностных дефектов. Плоскостные поверхностные дефекты (трещины, коррозионное растрескивание под напряжением) имитировались поверхностными пазы, выполненными электроэрозионным способом, а объемные поверхностные дефекты (язвенная, питтинговая коррозия) – вертикальными сверлениями.

Данные образцы, как это показано в [12, 13], содержали сверления глубиной 5 мм и диаметрами 1; 1,5; 2; 2,5; 3; 3,5; 4; 4,5; 5; 7; 8,5; 10 мм; сверления диаметром 3 мм и глубинами 0,25; 0,4; 0,5; 0,75; 1,0; 1,2; 1,5; 2,0; 2,5; 3,0; 3,5; 4,0; 4,5; 5,0 мм; пазы раскрытием 0,15 мм и глубинами 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,75; 1,0; 1,5; 2,0; 2,5; 3,0; 4,0 мм; пазы глубиной 0,5 мм и раскрытиями 0,15; 0,25; 0,5; 0,75; 1,0; 1,5 мм; пазы раскрытием 0,15 мм, глубиной 0,5 мм и углами наклона к поверхности образца 15°; 30°; 45°; 60°; 75°; 90°. Фотографии отдельных образцов с вертикальными сверлениями и электроэрозионными пазы представлены на рис. 1.

Ультразвуковые измерения выполнялись с использованием конфигурируемого блока дефектоскопической электроники Sonaflex [18], к которому был подключен бесконтактный электромагнитно-акустический преобразователь (ЭМАП), излучающий

релеевские волны с центральной частотой 1 МГц. В качестве параметра, измеряемого при ультразвуковом контроле, выступала максимальная амплитуда эхо-сигнала, отраженного от дефекта (рис. 2а). В данном случае время прихода эхо-сигнала, отраженного от поверхностного дефекта, не несет полезной информации, т.к. анализируется временная область, находящаяся в непосредственной близости от зондирующего импульса.

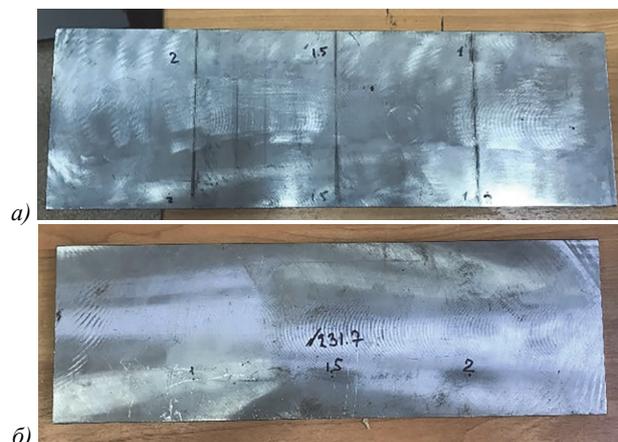


Рис. 1. Фото образцов с поверхностными дефектами: а) электроэрозионными пазы, б) вертикальными сверлениями

Помимо УК, также производился сбор данных вихрековым методом неразрушающего контроля (ВК). В работе [11] согласно отбору признаков было установлено, что для задачи классификации поверхностных дефектов по типам оптимальным является трансформаторный дифференциальный ВТП. Тот же ВТП карандашного типа фирмы Olympus с частотным диапазоном 500 кГц–3 МГц применялся для определения параметров дефектов. При вихрековом контроле сигнал от дефекта отображается на комплексной плоскости, при этом измеряется не только амплитуда, а также и фаза регистрируемого сигнала (рис. 2б). По результатам вихрековых измерений, проведенных на изготовленных образцах с поверхностными дефектами, были получены значения амплитуды и фазы вихрековых сигналов от искусственных дефектов на образцах.

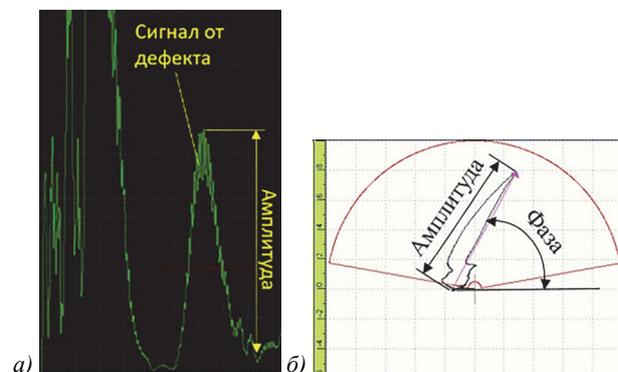


Рис. 2. Пример сигналов: а) ультразвукового, б) вихрекового

ВИК в автоматизированном режиме может быть реализован с применением камеры телевизионного контроля и лазерного триангуляционного датчика. В работах [19, 20] была разработана архитектура сверточной нейронной сети (CNN), позволяющая идентифицировать и производить локализацию питтинговой коррозии на изображениях, полученных камерой телевизионного контроля. Данная CNN имеет «сигмоиду» в качестве выходной функции активации, и результатом модели является вероятность (вещественное число от 0 до 1) наличия питтинговой коррозии на изображении (рис. 3).

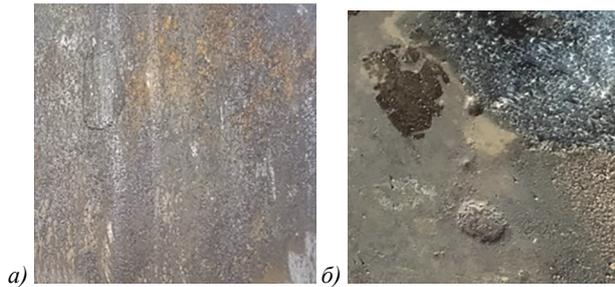


Рис. 3. Пример фото металлической поверхности:
 а) отсутствие коррозии (результат модели: 0,18);
 б) наличие питтинговой коррозии (результат модели: 0,81)

Лазерный триангуляционный датчик на выходе выдает результаты в виде набора координат точек, описывающих профиль сканируемой поверхности. При наличии поверхностного дефекта на профиле поверхности образуется каверна, которая имеет определенные глубину и ширину (рис. 4).

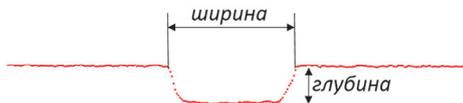


Рис. 4. Пример сканирования лазерным триангуляционным датчиком поверхностной каверны

На основе проведенных измерений была сформирована выборка, представляемая в виде таблицы, содержащей 6 столбцов, а именно значения амплитуды сигнала УК, значения амплитуды и фазы ВК, вероятность наличия питтинговой коррозии по результатам модели на основе CNN, ширина и глубина дефекта по результатам сканирования лазерным триангуляционным датчиком. Всего было произведено 269 измерений. Все дефекты, для которых были произведены измерения, разделялись на два класса: плоскостные и объемные. Для плоскостных дефектов определялась только глубина залегания, для объемных – глубина залегания и ширина.

2. Анализ полученного набора данных

Классифицировать поверхностные дефекты по результатам совместной обработки результатов УК и ВК удалось в работе [11] с высокой достоверностью, а также результаты той классификации дополнительно могут быть подтверждены с телевизионным контролем, оснащенный моделью компьютерного зрения

на основе CNN, позволяющей идентифицировать наличие питтинговой коррозии, то исходный набор данных разбивается на два набора данных: первый содержит измерения только для плоскостных дефектов (149 измерений), второй – только для объемных (120 измерений). В наборе данных для плоскостных дефектов целевой переменной является глубина дефекта, в наборе данных для объемных – глубина и ширина дефекта. Все целевые переменные являются непрерывными, поэтому данная задача определения параметров дефектов является задачей регрессии.

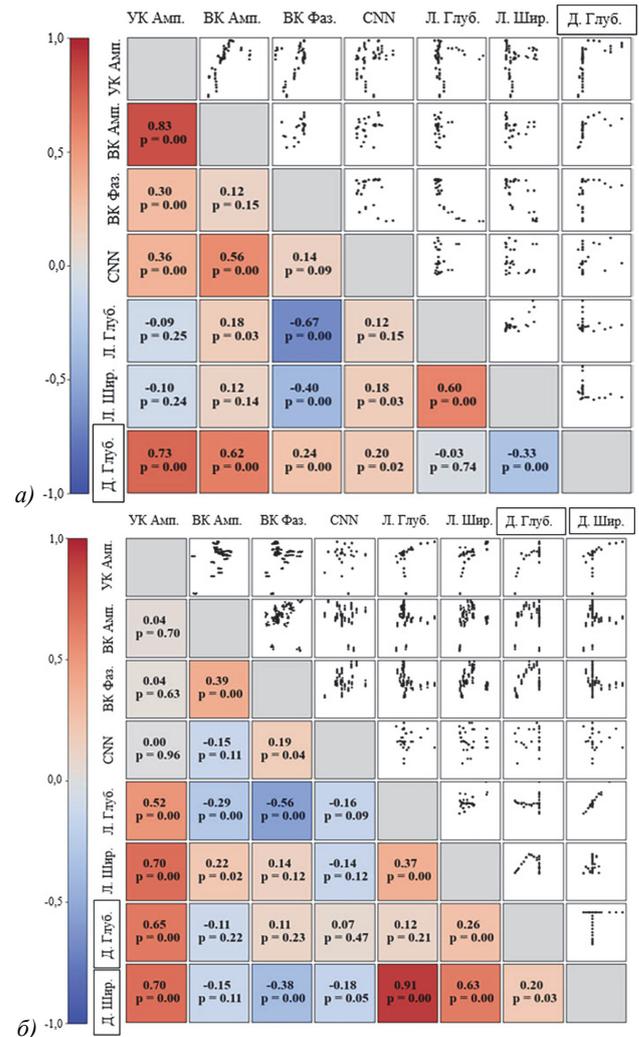


Рис. 5. а) Матрицы взаимной корреляции для набора данных с плоскостными дефектами; б) с объемными дефектами

Как правило, решение задач регрессии, в которых все входные переменные являются непрерывными, начинается с распечатки матрицы взаимной корреляции для исследования возможных зависимостей между различными переменными набора данных и оценки степени влияния отдельных переменных на целевую переменную. Матрицы взаимной корреляции обычно содержат значения коэффициента корреляции, который дублируется выше и ниже главной диагонали. Для исключения дублирующейся информа-

ции коэффициенты корреляции и соответствующие им p -уровни значимости будут размещены только под главной диагональю, а над главной диагональю будут помещены диаграммы рассеяния пар переменных набора данных. Поскольку большинство отношений переменных друг к другу имеют явную нелинейность, то в качестве коэффициента корреляции использовался коэффициент Спирмена [21]. Матрицы взаимной корреляции для наборов данных с объемными и плоскостными дефектами представлены на рис. 5.

Как видно из рис. 5а, с глубиной плоскостного дефекта просматривается зависимость у амплитуды ультразвукового и вихретокового сигнала с коэффициентами Спирмена, равными 0,73 и 0,62 соответственно. Анализируя рис. 5б, можно сказать, что с глубиной объемного дефекта присутствует зависимость только у амплитуды ультразвукового контроля с коэффициентом корреляции 0,65, с шириной объемного дефекта – присутствует зависимость у ампли-

туды ультразвукового контроля, ширины и глубины, определенной лазерным сканированием с соответствующими коэффициентами: 0,7; 0,91 и 0,63.

Помимо матрицы взаимной корреляции, также производилась оценка степени влияния различных признаков на целевые переменные с использованием дисперсионного анализа (ANOVA) и отбора признаков с применением алгоритма «экстра деревьев» (Extra Trees Classifier). В дисперсионном анализе (ANOVA) вычисляются значения коэффициента Фишера для имеющихся параметров (в нашем случае это амплитуда и фаза различных ВТП), и за оптимальные принимаются параметры с максимальными значениями коэффициента Фишера [22]. Помимо этого, на исследуемой выборке проводился отбор признаков с применением алгоритма «экстра деревьев» (Extra Trees Classifier), где определялся параметр степени влияния на задачу регрессии. Результаты отбора признаков для всех целевых переменных представлены в табл. 1.

Табл. 1. Результаты отбора признаков для регрессии

Параметры	Плоск. Глуб.		Об. Глуб.		Об. Шир.	
	ANOVA	ET	ANOVA	ET	ANOVA	ET
УК А.	17,3	0,282	64,6	0,57	5,4	0,141
ВК А.	5,3	0,135	9,7	0,24	8,1	0,007
ВК Ф.	2,4	0,299	8,6	0,1	4,6	0,004
CNN	3,5	0,09	7,3	0,067	2,3	0,012
Л. Г.	4,1	0,123	2,4	0,118	47,9	0,265
Л.Ш.	1,5	0,07	1,3	0,121	1229,0	0,571

Анализируя табл. 1, видно, что на определение глубины плоскостных дефектов максимальное влияние оказывает амплитуда сигнала УК (коэффициент Фишера ANOVA составляет 17,3, и параметр «экстра деревьев» составляет 0,282) и фаза сигнала ВК (параметр «экстра деревьев» составляет 0,299). На определение глубины объемных дефектов максимальное влияние оказывает амплитуда сигнала УК (коэффициент Фишера ANOVA составляет 64,6, и параметр «экстра деревьев» составляет 0,57) и амплитуда сигнала ВК (параметр «экстра деревьев» составляет 0,24). На определение ширины объемных дефектов максимальное влияние оказывает значение ширины, полученное в результате лазерного сканирования (коэффициент Фишера ANOVA составляет 1229,0, и параметр «экстра деревьев» составляет 0,571) и значение глубины, полученное в результате лазерного сканирования (коэффициент Фишера ANOVA составляет 47,9, и параметр «экстра деревьев» составляет 0,265).

В итоге, проанализировав результаты матриц взаимной корреляции и отбора признаков, можно сказать, что на определение глубины плоскостных дефектов основное влияние оказывают амплитуда сигналов УК и ВК, а также фаза ВК. На определение глубины объемных дефектов основное влияние оказывают амплитуда сигналов УК и ВК. На определение ширины объемных дефектов основное влияние оказывают показания лазерного сканирования и ам-

плитуда сигнала УК. Получается, что для определения типа дефекта и его параметров каждый метод НК вносит свой отдельный вклад.

3. Построение моделей регрессии

Модели регрессии на исследуемых наборах данных для описанных целевых переменных строились на основе следующих алгоритмов: метод опорных векторов [23], дерево решений [24], случайный лес [25], градиентный бустинг [26], линейная регрессия, полиномиальная регрессия с L1 регуляризацией [21], многослойный перцептрон (МСП) [27]. В основе метода опорных векторов для задач регрессии лежит поиск гиперплоскости, при которой риск в многомерном пространстве будет минимальным. По сравнению с традиционными моделями регрессии метод опорных векторов оценивает коэффициенты путем минимизации квадратичных потерь. Так, если прогнозное значение попадает в область гиперплоскости, то потери равны нулю, в противном случае они равны разности прогнозного и фактического значений. Дерево решений – это дерево, в листьях которого стоят значения целевой функции, а в остальных узлах – условия перехода, определяющие, по какому из ребер идти. Если для данного наблюдения условие «истина», то осуществляется переход по левому ребру, если же «ложь» – по правому. Случайный лес (Random Forest) использует ансамбль деревьев решений, тем

самым увеличивая точность прогнозирований. Градиентный бустинг также использует ансамбль деревьев решений, но тут деревья решений применяются последовательно. В градиентном бустинге последующие деревья решений учатся на ошибках предыдущих. Линейная регрессия является наиболее распространенным способом решения задач регрессии, при которой методом наименьших квадратов строится полиномиальная зависимость от целевой переменной входных переменных. При полиномиальной регрессии строится подобная зависимость, только в виде полинома определенной степени. L1 регуляризация уменьшает переобучение моделей путем добавления штрафа, равного абсолютному значению коэффициентов модели. Многослойный перцептрон является классом искусственных нейронных сетей прямого распространения, состоящих как минимум из трех слоёв: входного, скрытого и выходного. За исключением входных, все нейроны используют нелинейную функцию активации.

Все рассматриваемые модели имеют ряд гиперпараметров. Подбор гиперпараметров происходил автоматически случайным поиском. Модели на основе метода опорных векторов для определения глубин плоскостных и объемных дефектов имели ядро типа "Radial Basis Function", которое позволяет разделять линейно неразделимые данные, а модель для определения ширины объемных дефектов – линейное ядро. Гиперпараметры моделей на основе деревьев решений представлены в табл. 2.

Табл. 2. Гиперпараметры моделей на основе деревьев решений

Гиперпараметр	Плоск. Глуб.	Об. Глуб.	Об. Шир.
Максимальная глубина дерева	6	46	10
Минимальное количество выборок, для разделения узла	5	6	3
Минимальное количество образцов в листовом узле	1	1	3

Гиперпараметры моделей на основе случайного леса представлены в табл. 3.

Табл. 3. Гиперпараметры моделей на основе случайного леса

Гиперпараметр	Плоск. Глуб.	Об. Глуб.	Об. Шир.
Количество деревьев решений	252	1988	1988
Максимальная глубина дерева	20	46	46
Минимальное количество выборок, для разделения узла	9	3	3
Минимальное количество образцов в листовом узле	1	1	1

Гиперпараметры моделей на основе градиентного бустинга представлены в табл. 4.

Табл. 4. Гиперпараметры моделей на основе градиентного бустинга

Гиперпараметр	Плоск. Глуб.	Об. Глуб.	Об. Шир.
Количество деревьев решений	2404	915	571
Темп обучения	0,837	0,135	0,405
Максимальная глубина дерева	24	42	24
Минимальное количество выборок, для разделения узла	34	24	30
Минимальное количество образцов в листовом узле	35	9	2

В моделях на основе полиномиальной регрессии использовался полином 8-й степени, параметры L1 регуляризации, равной 0,5. Модель на основе МСП имела 5 внутренних слоев, имеющих 100, 80, 60, 40 и 20 нейронов соответственно (рис. 6). В качестве функции активации на всех нейронах выступала функция ReLU: $f(x) = \max(x, 0)$. Темп обучения был постоянным и составлял 0,001, также использовалась L2 регуляризация с параметром 0,01. Обучение модели происходило с использованием алгоритма оптимизации Adam, максимальное количество итераций не превышало 1000.

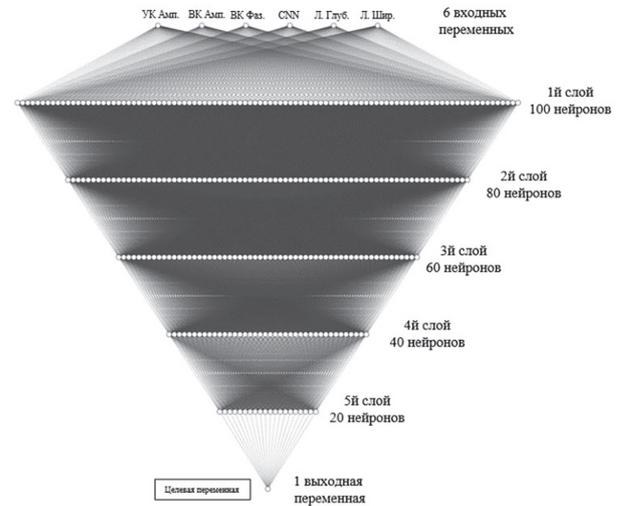


Рис. 6. Схема модели регрессии на основе МСП

4. Оценка работоспособности моделей

Для обучения и проверки работоспособности моделей классификации применялась кросс-валидация, при которой производились 30 итераций, где все данные, полученные при измерениях, были разделены на 5 различных обучающих и тестовых выборок, составивших 215 и 54 элемента соответственно.

Работоспособность моделей регрессии на тестовой выборке определялась по средним арифметическим для всех итераций кросс-валидации таких метрик, как

средняя абсолютная ошибка (MAE) и корень из средне-квадратичной ошибки (RMSE), которые вычисляются по формулам (1) и (2) соответственно.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \tag{1}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \tag{2}$$

где n – количество наблюдений, по которым строится модель и количество прогнозов, y_i – фактические значения зависимой переменной для i -го наблюдения, \hat{y}_i – значение зависимой переменной, предсказанное моделью.

Результаты тестирования моделей, определяющих глубину плоскостных дефектов, представлены в табл. 5.

Табл. 5. Результаты тестирования моделей, определяющих глубину плоскостных дефектов

Алгоритм	Ср. MAE обуч.	Ср. MAE тест.	Ср. RMSE обуч.	Ср. RMSE тест.
Метод опорных векторов	0,379	0,387	0,823	0,803
Дерево решений	0,001	0,031	0,004	0,137
Случайный лес	0,092	0,141	0,203	0,307
Градиентный бустинг	0,011	0,032	0,016	0,071
Линейная регрессия	0,450	0,482	0,634	0,666
Полиномиальная регрессия	0,029	0,051	0,041	0,085
МСП	0,277	0,304	0,515	0,549

Табл. 6. Результаты тестирования моделей, определяющих глубину объемных дефектов

Алгоритм	Ср. MAE обуч.	Ср. MAE тест.	Ср. RMSE обуч.	Ср. RMSE тест.
Метод опорных векторов	0,795	0,827	1,032	1,057
Дерево решений	0,012	0,158	0,054	0,444
Случайный лес	0,070	0,189	0,150	0,355
Градиентный бустинг	0,002	0,103	0,003	0,199
Линейная регрессия	0,716	0,770	0,911	0,959
Полиномиальная регрессия	0,207	0,398	0,308	0,610
МСП	0,339	0,397	0,579	0,646

Как видно из табл. 5, 6, 7, минимальные значения метрик MAE и RMSE на тестовой выборке имеют модели на основе градиентного бустинга. Значения RMSE для целевой переменной в виде глубины плоскостных дефектов составляет 0,071 мм, для глубины объемных дефектов – 0,199 мм, для ширины объемных дефектов – 0,053 мм.

По результатам работы было получено три различных модели на основе градиентного бустинга, ко-

торые в качестве входных данных получают параметры систем контроля, а именно значения амплитуды сигнала УК, значения амплитуды и фазы ВК, вероятность наличия питтинговой коррозии по результатам модели на основе CNN, ширину и глубину дефекта по результатам сканирования лазерным триангуляционным датчиком, а на выходе выдают глубину плоскостных и объемных дефектов, а также ширину объемных дефектов. Данные модели использованы в общем алгоритме совместной обработки результатов при комплексной диагностике, который представлен на рис. 7.

Табл. 7. Результаты тестирования моделей, определяющих ширину объемных дефектов

Алгоритм	Ср. MAE обуч.	Ср. MAE тест.	Ср. RMSE обуч.	Ср. RMSE тест.
Метод опорных векторов	0,094	0,097	0,13	0,131
Дерево решений	0,008	0,062	0,041	0,165
Случайный лес	0,026	0,067	0,065	0,143
Градиентный бустинг	0,001	0,019	0,001	0,053
Линейная регрессия	0,087	0,092	0,126	0,130
Полиномиальная регрессия	0,045	0,074	0,064	0,101
МСП	0,082	0,091	0,118	0,127

Суть алгоритма совместной обработки результатов при комплексной диагностике следующая: по значениям амплитуды сигнала УК, значения амплитуды и фазы ВК с применением модели классификации, разработанной в [10], происходит определение типа дефекта – плоскостной (трещины, КРН) или объемный (язвенная, питтинговая коррозия), после чего наличие/отсутствие объемных дефектов сопоставляется с результатами работы модели на основе CNN. В случае классификации на плоскостные дефекты запускается работа регрессора, определяющего глубину плоскостных дефектов по 6 входным параметрам. В случае классификации на объемные дефекты запускается работа двух регрессоров, определяющих глубину и ширину объемных дефектов соответственно по 6 входным параметрам. В алгоритме используются те модели, которые имели наилучшие показатели по метрикам MAE и RMSE при кросс-валидации. Итоговое значение RMSE по определению параметров дефектов на тестовом наборе составило 0,011 мм, при этом 70 из 78 измерений (90 %) находились в пределах одного RMSE, 73 из 78 измерений (94 %) находились в пределах двух значений RMSE.

Заключение

1. Сформирован набор данных по результатам измерений при комплексной диагностике основного металла магистральных газопроводов, состоящий

из 269 измерений, в котором содержатся следующие входные переменные: амплитуда сигнала при ультразвуковом контроле, амплитуда сигнала при вихретоковом контроле, фаза сигнала при вихретоковом контроле, показания системы телевизи-

онного контроля, глубина и ширина дефекта, полученные по результатам лазерного сканирования. В качестве целевых переменных рассматриваемых данных содержит глубину плоскостных дефектов, глубину и ширину объемных дефектов.

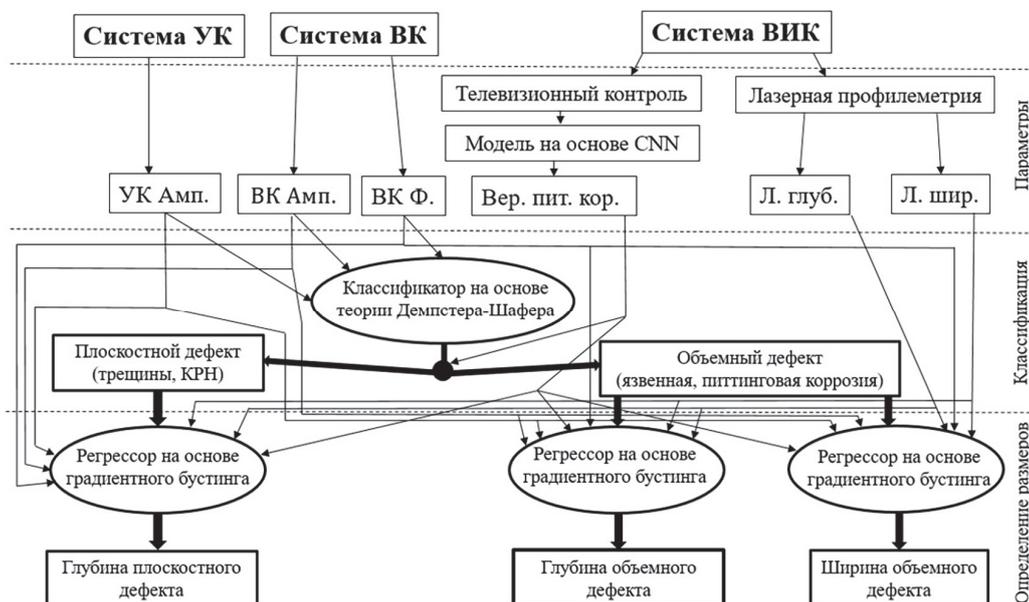


Рис. 7. Алгоритм совместной обработки результатов при комплексной диагностике

2. Определена степень влияния параметров различных систем неразрушающего контроля при комплексной диагностике на определение параметров плоскостных и объемных дефектов на основе анализа матриц взаимной корреляции Спирмена, дисперсионного анализа (ANOVA) и отбора признаков с применением алгоритма «экстра дерева». Установлено, что на определение глубины плоскостных дефектов основное влияние оказывают амплитуда сигналов УК и ВК, а также фаза ВК. На определение глубины объемных дефектов основное влияние оказывают амплитуда сигналов УК и ВК. На определение ширины объемных дефектов основное влияние оказывают показания лазерного сканирования и амплитуда сигнала УК. В итоге выходит, что для определения типа дефекта и его параметров каждый метод НК вносит свой отдельный вклад.
3. Исследуемый набор данных был разделен на тренировочную и тестовую выборки, на которых были обучены модели на основе следующих алгоритмов: метод опорных векторов, дерево решений, случайный лес, градиентный бустинг, линейная регрессия, поли-номиальная регрессия с L1 регуляризации и многослойный перцептрон. Обучение и случайный поиск гиперпараметров для моделей на основе рассматриваемых алгоритмов проводилось для всех целевых переменных по отдельности. Наиболее оптимальными моделями для всех трех переменных оказались модели на основе градиентного бустинга со средними значениями в ре-

- зультате кросс-валидации метрик RMSE 0,071 мм, для глубины объемных дефектов – 0,199 мм, для ширины объемных дефектов – 0,053 мм.
4. Представлен итоговый алгоритм совместной обработки результатов при комплексной диагностике, в котором применяются три полученные модели определения параметров дефектов, показавшие наилучшие значения по метрикам MAE и RMSE при кросс-валидации.
 5. Оценена общая точность работы алгоритма по метрике RMSE на тестовой выборке, которая составила 0,011 мм, при этом 70 из 78 измерений (90%) находились в пределах одного RMSE, 73 из 78 измерений (94%) находились в пределах двух значений RMSE. Применение данного алгоритма позволит проводить оценку качества трубопровода при его капитальном ремонте с применением только методов НК в автоматизированном варианте без трудоемкого ручного подтверждающего контроля.

References

- [1] Davydova DG. Defects in process pipelines: typology, assessment of the impact on operation [In Russian]. Prombezopasnost-Priuralye 2012; 8: 24-28.
- [2] Yerekhinsky BA, Maslakov SV, Shustov NI, Mitrofanov AV, Baryshov SN, Zaryaev MYu, Kravtsov AV, Yegorov SV. Cracking of metal housings of Christmas-tree gate valves of northern fields gas producers [In Russian]. Territoria Neftegaz 2014; 2: 31-36.
- [3] Safina IS, Kuzova PA, Gushchin DA. Assessment of the technical condition of vertical steel tanks [In Russian]. TehNadzor 2016; 3(112): 39-42.

- [4] Butusov DS, Egorov SI, Zavyalov AP, Lyapichev DM. Stress corrosion cracking of gas pipelines: Textbook [In Russian]. Moscow: Publishing Center of the Russian State University of Oil and Gas named after I.M. Gubkin; 2015.
- [5] Kalinichenko NP, Vasiliev MA. Atlas of defects in welded joints and base metal: teaching aid [In Russian]. Tomsk: Publishing House of Tomsk Polytechnic University; 2006. ISBN: 978-5-98298-908-6.
- [6] Aleshin NP. Physical methods of non-destructive testing of welded joints: textbook [In Russian]. 2nd ed., revised and additional. Moscow: Innovative Engineering Publisher; 2019. ISBN: 978-5-94275-695-6.
- [7] Hall DL, McMullen SAH. Mathematical techniques in multisensor data fusion. 2nd ed. Norwood, MA: Artech House Inc; 2004. ISBN: 978-1-58053-335-5.
- [8] Meyer SL. Data analysis for scientists and engineers. Peer Management Consultants Ltd; 1992. ISBN: 978-0-9635027-0-4.
- [9] Gros XE. NDT data fusion. London, UK: Arnold; 1997. ISBN: 978-0340676486.
- [10] Gros XE. Applications of NDT data fusion. New York: Springer; 2001. ISBN: 978-0-7923-7412-1.
- [11] Aleshin NP, Skrynnikov SV, Krysko NV, Shchipakov NA, Kusyy AG. Classification of surface defects in the base metal of pipelines based on complex diagnostics results. *Computer Optics* 2023; 47(1): 170-178. DOI: 10.18287/2412-6179-CO-1185.
- [12] Aleshin NP, Krysko NV, Kusyy AG, Skrynnikov SV, Mogilner LY. Investigating the detectability of surface volumetric defects in ultrasonic testing with the use of rayleigh waves generated by an electromagnetic-acoustic transducer [In Russian]. *Russian Journal of Nondestructive Testing* 2021; 57(5): 361-368. DOI: 10.31857/S0130308221050031.
- [13] Aleshin NP, Krysko NV, Skrynnikov SV, Kusyy AG. Studying detectability of plane surface defects by ultrasonic method using rayleigh waves [In Russian]. *Russian Journal of Nondestructive Testing* 2021; 57(6): 446-454. DOI: 10.31857/S0130308221060038.
- [14] Ryakhovskikh IV, Kaverin AA, Petukhov IG, Lipovik AV, Selivanov AA, Sakhon AV. Estimation of the size of stress-corrosion defects during technical diagnostics of gas pipelines [In Russian]. *Vesti Gazovoi Nauki* 2020; 2(44): 4-14.
- [15] Shlyakhtenkov SP, Bekher SA. Technology for estimating the depth of surface cracks in rails by eddy current method [In Russian]. Polytransport Systems: XI Int Scientific and Technical Conf, Novosibirsk 2020: 608-613.
- [16] Alekhin SG, Samokrutov AA, Shevaldykin VG. Measuring the depth of stress-corrosion cracks in main gas pipelines [In Russian]. *Vesti Gazovoi Nauki* 2022; 1(50): 78-83.
- [17] Shubochkin AE. Development and current state of the eddy current method of non-destructive testing: monograph [In Russian]. Moscow: Spektr Publishing House; 2014.
- [18] SONAFLEX multipurpose test electronics unit. 2024. Source: <<https://nordinkraft.de/sonaflex/>>.
- [19] Malashin I, Tynchenko V, Nelyub V, Borodulin A, Gantimurov A, Krysko N.V, Shchipakov NA, Kozlov DM, Kusyy AG, Martysyuk D, Galinovsky A. Deep Learning Approach for Pitting Corrosion Detection in Gas Pipelines. *Sensors* 2024, 24, 3563. <https://doi.org/10.3390/s24113563>.
- [20] Krysko NV, Schipakov NA, Kozlov DM, Kusyy AG. Identification and localization of pitting corrosion on metallic surface using deep learning. *CIS Iron and Steel Review*; 27 (2024), pp. 96–102.
- [21] Dodge Y. The concise encyclopedia of statistics. Springer Science+Business Media LLC; 2008. ISBN: 978-0-387-32833-1.
- [22] Barker TB, Milivojevich A. Quality by experimental design. Boca Raton, FL: CRC Press, Taylor & Francis Group LLC; 2016. ISBN: 978-1-4822-4967-5.
- [23] Cortes C, Vapnik V. Support-vector networks. *Mach Learn* 1995; 20: 273-297. DOI: 10.1007/BF00994018.
- [24] Rokach L, Maimon O. Decision trees. In Book: Maimon O, Rokach L, eds. Data mining and knowledge discovery handbook. New York, NY: Springer Science+Business Media Inc; 2005: 165-192. DOI: 10.1007/0-387-25465-X_9.
- [25] Breiman L. Random forests. *Mach Learn* 2001; 45: 5-32. DOI: 10.1023/A:1010933404324.
- [26] He Z, Lin D, Lau T, Wu M. Gradient boosting machine: A survey. arXiv Preprint. 2019. Source: <<https://arxiv.org/abs/1908.06951>>. DOI: 10.48550/arXiv.1908.06951.
- [27] Murphy KP. Probabilistic machine learning. An introduction. Cambridge, MA: The MIT Press; 2022. ISBN: 9780262046824.

Сведения об авторах

Крысько Николай Владимирович, 1988 года рождения, к.т.н, работает доцентом кафедры МТ-7 «Технологии сварки и диагностики» в МГТУ им. Н.Э. Баумана. Область научных интересов: неразрушающий контроль, анализ данных, компьютерное зрение, машинное обучение, глубокое обучение, статистический анализ. E-mail: kryskov@bmstu.ru

Скряиников Сергей Владимирович, 1972 года рождения, работает руководителем департамента в ПАО «Газпром». Область научных интересов: неразрушающий контроль, ультразвуковой контроль, вихретоковый контроль, анализ данных, машинное обучение, статистический анализ. E-mail: S.Skrynnikov@adm.gazprom.ru

Щипаков Никита Андреевич, 1986 года рождения, к.т.н, работает доцентом кафедры МТ-7 «Технологии сварки и диагностики» в МГТУ им. Н.Э. Баумана. Область научных интересов: неразрушающий контроль, ультразвуковой контроль, анализ данных, статистические методы управления качеством. E-mail: shchipak@bmstu.ru

Козлов Денис Михайлович, 1984 года рождения, к.т.н, работает инженером в МГТУ им. Н.Э. Баумана. Область научных интересов: неразрушающий контроль, визуальный и измерительный контроль, ультразвуковой контроль, анализ данных. E-mail: denvwb5@mail.ru

Кусый Андрей Геннадьевич, 1992 года рождения, работает инженером в МГТУ им. Н.Э. Баумана. Область научных интересов: неразрушающий контроль, ультразвуковой контроль, вихретоковый контроль, машинное обучение, анализ данных, статистический анализ. E-mail: andrei.k.166@mail.ru

ГРНТИ: 59.45

Поступила в редакцию 6 октября 2023 г. Окончательный вариант – 05 июня 2024 г.

Determining parameters of surface defects in the base metal of pipelines using results of complex diagnostics

N.V. Krysko¹, S.V. Skrynnikov², N. A. Shchipakov¹, D.M. Kozlov¹, A.G. Kusyy¹

¹ Bauman Moscow State Technical University,

2nd Baumanskaya St. 5, building 1, Moscow, 105005, Russia;

² PJSC Gazprom, 16 Nametkina St., Moscow, GSP-7, 117997, Russia

Abstract

We discuss issues of determining surface operational defects parameters using results of complex diagnostics including ultrasonic, eddy current and visual non-destructive testing methods. We note that the visual method is implemented using a television camera with a computer vision function and a laser triangulation sensor. The study presents a data set in which the non-destructive testing results are used as input variables, with the depth of planar and volumetric defects and the width of volumetric defects used as target variables. The study also assesses the degree of influence of various non-destructive testing results on the determination of target variables. Models are trained using various algorithms. Finally, the models based on gradient boosting are found to be optimal for all target variables. We propose an algorithm for combined processing of the results of complex diagnostics in which the obtained models are used. The accuracy of the proposed algorithm determined using the RMSE metric is found to be 0.011 mm.

Keywords: surface defects, ultrasonic testing, eddy current testing, complex diagnostics, data fusion, machine learning, regression.

Citation: Krysko NV, Skrynnikov SV, Shchipakov NA, Kozlov DM, Kusyy AG. Determining parameters of surface defects in the base metal of pipelines using results of complex diagnostics. *Computer Optics* 2025; 49(2): 311-319. DOI: 10.18287/2412-6179-CO-1437.

Authors' information

Nikolay Vladimirovich Krysko (b. 1988), Ph.D., works as the associate professor of the MT-7 " Welding and testing technologies " at the Bauman Moscow State Technical University. Research interests: non-destructive testing, data analysis, computer vision, machine learning, deep learning, statistical analysis. E-mail: kryskonv@gmail.com

Sergei Vladimirovich Skrynnikov (b. 1972), works as a department head at PJSC Gazprom. Research interests: non-destructive testing, ultrasonic testing, eddy current testing, machine learning, data analysis, statistical analysis. E-mail: S.Skrynnikov@adm.gazprom.ru

Nikita Andreevich Shchipakov (b. 1986), Ph.D., works as the associate professor of the MT-7 " Welding and testing technologies " at the Bauman Moscow State Technical University. Research interests: non-destructive testing, ultrasonic testing, data analysis, statistical methods of quality management. E-mail: shchipak@bmstu.ru

Denis Mikhailovich Kozlov (b. 1984), Ph.D., works as an engineer at the Bauman Moscow State Technical University. Research interests: non-destructive testing, visual testing, ultrasonic testing, data analysis. E-mail: denvwb5@mail.ru

Andrey Gennadievich Kusyy (b. 1992), works as an engineer at the Bauman Moscow State Technical University. Research interests: non-destructive testing, ultrasonic testing, eddy current testing, machine learning, data analysis, statistical analysis. E-mail: andrei.k.166@mail.ru

Received October 06, 2023. The final version – Jyne 05, 2024
